



2009ko apirilaren 29a



Morfologia eta sintaxiko ariketak konputagailuaren bidez

M. Arantzabe <maxux.aranzabe@ehu.es>
K. Sarasola <kepa.sarasola@ehu.es>

Aurkibidea

<u>Aurkibidea</u>	2
<u>1 Sarrera</u>	3
1.1 Motibazioa.....	3
1.2 Helburuak.....	3
1.3 Metodologia.....	3
<u>2 Euskararen morfologia lantzen:</u>	
Morfeus, hitza isolatuta.....	4
2.1 Analisi morfologikoa martxan: Morfeus	4
2.2 Kategoria multzoa.....	5
2.3 Ariketak.....	6
<u>3 Euskararen morfologia lantzen:</u>	
Eustagger, hitza bere testuinguruan.....	7
3.1 Eustagger martxan.....	7
3.2 Ariketak.....	8
<u>4 Euskararen sintaxia lantzen: AnCora, Zatiak eta Eihera</u>	9
4.1 Ancora: esaldi analizatuak konsultatzetan.....	9
4.2 Ariketa:.....	12
4.3 Zatiak (azaleko sintaxia) eta Eihera (entitateak) sintaxi-tresnak.....	13
4.4 Ariketa15	
<u>5 Euskararako beste tresna linguistiko batzuk</u>	17
<u>6 Gaztelania lantzen:</u>	
Freeling eta Ancora.....	18
6.1 Kategoria multzoa.....	18
6.2 Ariketa:.....	19
6.3 Freeling	20
6.4 Ancora.....	22
<u>7 Ingelesa lantzen.</u>	
Freeling eta Conexor.....	23
7.1 Kategoria multzoa.....	23
7.2 Freeling.....	24
<u>8 Bibliografia</u>	25
Oinarrizko bibliografia.....	25
Bestelako bibliografia.....	25
<u>9 Eranskinak</u>	26
9.1 Euskararen kategoria multzoa.....	26
9.2 Gaztelaniaren kategoria multzoa.....	28
9.3 Ingelesaren kategoria multzoa.....	32
9.3.1 Clause Level.....	32
9.3.2 Phrase Level.....	32
9.3.3 Word level.....	33
9.3.4 Function tags. Form/function discrepancies.....	33
9.3.5 Function tags. Grammatical role.....	34
9.3.6 Function tags. Adverbials.....	34
9.3.7 Function tags. Miscellaneous.....	35

1 Sarrera

1.1 Motibazioa

Linguistika konputazionalaren arloak informazio linguistikoarekin egiten du lan. Izan ere, konputagailuak linguistikari eskaini dion ekarpen nagusia testu handiekin hainbat datu ateratzea baita, datu horiek analizatu, eta analisi horretatik hainbat ondorio ateratzeko aukera emanez. Egun hainbat aukera dira analisi morfologiko eta sintaktikoa automatikoki lortzeko. Tresna horietako batzuk Interneten erabil daitezke publikoki hitzen analisi morfologiko eta esaldien analisi sintaktikoa automatikoki egiteko, Morfeus, Ancora eta Freeling adibidez. Tresna horiek eskolako edota institutuko ikasleentzat sintaxia eta morfologia ordenagailuarekin lantzeko erakargarriak izan daitezke, zuhaitzak modu grafikoan ikusten direlako edo hainbat proba di-da egin daitezkeelako.

1.2 Helburuak

Oinarrizko ariketa bilduma sortu ahal izateko zenbait baliabide aurkeztu nahi ditugu ikastaro honetan. Egun hainbat aukera dira Interneten analisi morfologiko eta sintaktikoa automatikoki lortzeko. Ezagutu behar dira guneak eta emaitzak erakusteko moduak, alegia erabiltzen diren formatuak, egiturak, kategoriak eta azpikategoriak. Hauek dira ikastaroaren helburu zehatzak:

- Euskarazko hitzak eta esaldiak Internet bidez, analizatzen jakitea.
- Analisien emaitzetan azaltzen diren kategoriak ondo ezagutzea.
- Hainbat ariketa egitea eta ariketa berriak asmatzeko erraztasuna lortzea.
- Gaztelaniaz eta ingelesezko ariketekin ere antzera.

1.3 Metodologia

Aztertuko dira Interneten bidez analisi morfologiko eta sintaktikoa egiteko dauden zenbait aukera. Emaitzak interpretatzeko behar diren kategoria eta azpikategoriak ondo ezagutzeko hainbat ariketa egingo dira konputagailuan. Bukaeran ikastaroko partaideek eurek asmatu beharko dituzte ariketa berriak, gero beren ikasleekin gelan erabili ahal izango dituztenak.

Batez ere euskararako egingo da, baina espainiera eta inglesa ere landuko dira.

2 Euskararen morfologia lantzen: Morfeus, hitza isolatuta.

2.1 Analisi morfologikoa martxan: Morfeus

Bilatu Morfeus, euskarako analizatzaile morfologikoaren demoa Interneten. Horretarako jo ezazu zuzenean helbide honetara:

http://ixa2.si.ehu.es/demo/analisi_anali.jsp

Edo IXA taldearen orritik (ixa.si.ehu.es) abiatuta, aukeratu *Demoak* ezkerreko menuan, bertan aukeratu “*Morfeus: analisi morfologikoa*” eta lehen eman dugun helbide berera ailegatuko zara.

Morfeus analizatzaile morfologikoa zuzenean nola dabilen ikusiko dugu. Orri horretan zaudela idatz ezazu ‘Analisi Morfologikoa’ leihotxoan “*Amagoiaren lagunak Galizian egiten du lan.*” esaldia eta sakatu *Analizatu* botoia. Honako leihoko bat zabalduko da hitz bakoitzak izan ditzakeen analisi morfologiko guztiekin:

Amagoiaren	lagunak	Galizian	egiten	du	lan
<i>Amagoia+en</i> IZEIZB+GEN	<i>lagun+ak</i> IZEARR+ABS	<i>Galizia+0+n</i> IZELIB+Sar+INE	<i>egin+te+n</i> ADISIN+AMM+INE	<i>du</i> ADL	<i>landu+0</i> ADISIN+AMM
<i>Amagoia+en+0</i> IZEIZB+GEN+ABS	<i>lagun+ak</i> IZEARR+ERG		<i>egin+0+ten</i> ADISIN+AMM+ASP	<i>du</i> ADT	<i>lan</i> IZEARR
<i>amagoi+aren</i> IZEARR+GEN	<i>lagun+ak</i> ADJARR+ABS				<i>lan+0</i> IZEARR+ABS
<i>amagoi+aren+0</i> IZEARR+GEN+ABS	<i>lagun+ak</i> ADJARR+ERG				

Analisi bakoitzean bi lerro azaltzen dira, batean letra urdinetan ikusten dira hitzaren barruan identifikatu diren lema eta flexio-atzizkiak (adibidez: *Amagoia+en*), eta bigarren lerroan, letra gorritan, hitzaren informazio morfológikoa ikusten da hurrenez hurren (adibidez: IZEIZB+GEN; hau da, *Amagoia* IZEn kategoriako hitza dela, zehatzago esanda, izen berezia (IZB) eta *en* atzizkia, GENitibo kasuaren erlazio-atzizkia daramala).

Ondoko atalean erakusten da zein diren kategoria nagusiak. Kategoria nagusiaz gain azpikategoria ere erakusten da analisian, esate baterako IZEARR eta IZEIZB azaltzen dira analisietan. Kasu bietan, kategoria nagusia izena da (IZE), baina kasu batean azpikategoria ARR da (IZEARR: izen arrunta) eta bestean IZB (IZEIZB: izen berezia).

2.2 Kategoria multzoa

Euskalazko hitzak morfológikoki bereizteko Morfeusek erabiltzen dituen kategoria nagusiak hauek dira:

- IZE izenak
- ADJ adjektiboak
- ADI aditzak
- ADB adberbioak
- DET determinatzaileak

- IOR izenordainak
- LOT loturazkoak
- PRT partikulak (omen, ote...)
- ITJ interjekzioak (alajaina!)
- BST bestelakoak (baldin)
- ADL aditz laguntzaileak (du)
- ADT aditz sintetikoak edo trinkoak (dator)
- SIG siglak (EHU)
- SNB sinboloak (km, cm, g...)
- LAB laburdurak (etab.)

Kategoria-sistema osoa lehenengo eranskinean dago azalduta, 9.1. atalean, alegia; hor ikus daitezke kategoria eta azpikategoriak. Ixa taldeko demoetan ere ikus daitezke kategoria horiek, emaitzak erakutsi eta gero esteka bat eskaintzen baita kategoria guztiak beste leihoa berri batean erakusteko (<http://ixa2.si.ehu.es/edblkonsulta/labureus.htm>).

2.3 Ariketak

A. Analizatu morfologikoki Morfeus erabiliz honako hitzak eta esaldiak:

1. Itxura hori zuen gizonak ikusi du.
2. Haurrak bizkor esan zuen etorriko zela.
3. duen, zioen, nuen, gazte, gorri, gaur, ikusten, ikus, alajaina, omen.
4. Nik huts egiten ez baldin badut, aurten ekarriko ditugu.
5. Bart Paris hoteleko zure gela arakatu egin dute
6. Gaur izebari omenaldia egin diote herrian.
7. *Nik iaz Parisera joan nintzen.
8. Nik iaz Parisera joateko aukera aprobetxatu egin nuen.

B. Xuxen zuzentzaile ortografikoak “or” hitza ez du gaizkitzat hartzen, zergatik?

Ez luke gorriaz pimarratu behar? Letra bat behar ote luke hasieran? Aztertu ea analisi posiblerik dagoen “or” hitzerako. Berdin joka zenezake Xuxenek ontzat hartzen dituenekin nahiz eta zuretzat txarto egon.

3 Euskararen morfologia lantzen: Eustagger, hitza bere testuinguruan

3.1 Eustagger martxan

Aurreko atalean “*Amagoiaren lagunak Galizian egiten du lan.*” esaldia analizatzean, hitz bakoitzeko analisi posibleak lortu ditugu. Analisi horietatik guztietatik zein da egokiena, ordea?

Hori da hain zuzen ere, Eustagger lematizatzairearen bitartez lortuko duguna. Horretarako, bilatu Eustagger lematizatzairearen demoa Interneten. Jo ezazu zuzenean helbide honetara: <http://ixa2.si.ehu.es/demo/analismorf.jsp>. Edo lehen bezala, IXA taldearen orritik (ixa.si.ehu.es) abiatuta, aukeratu *Demoak* ezkerreko menuan eta bertan aukeratu “*Eustagger: lematizatzalea eta etiketatzalea*”. Lehen eman dugun helbide berera ailegatuko zara: <http://ixa2.si.ehu.es/demo/analismorf.jsp>.

Bertan ageri den leihotxoan lehengo esaldi bera jartzen badugu (“*Amagoiaren lagunak Galizian egiten du lan.*”), orain lematizatzairearekin lortuko dugun emaitza ez da analizatzairearekin lortzen genuen bera. Hitz bakoitzak analisi bakarra emango du, ondoko irudian ikus daitekeen bezalaxe.

Amagoiaren	lagunak	Galizian	egiten	du	lan	.
<i>Amagoia IZEIZB</i>	<i>lagun IZEARR</i>	<i>Galizia IZELIB</i>	<i>egin ADI</i>	<i>*edun ADL</i>	<i>lan IZEARR</i>	<i>.</i>

Gizakontzat oso erraza da geure hizkuntza ulertzea, konputagailuari asko kostatzen zaio, ordea. Adibidez, testu bateko hitzak irakurtzen ditugunean, guk ez ditugu kontuan hartzen ezohiko diren interpretazio bitxiak, baina konputagailuak bai, denak aztertu behar ditu eta. Programa lematizatzaleek laguntzen diote konputagailuari perpaus bateko hitz bakoitzari dagokion interpretazio morfologiko egokia aukeratzen.

Argi dago Morfeus analizatzaleak hitz bakoitza testuingurua kontuan hartu gabe analizatzen duela. Erabili dugun perpusean *lagunak* hitza adjektiboa ere izan daitekeela

dio; *du* hitza aditz trinkoa ere izan daitekeela, nahiz eta aurreko hitza *egiten* izan; edo *ikusi* hitza izena.

Geroago analizatu dugu esaldi bera lematizatzailarekin. Lematizatzailak analisi morfologikoa egiten du, baina hitzaren testuingurua aztertuta hitz bakoitzerako analisi bakarra aukeratzen du.

Morfeus analizatzaila morfologikoak batez beste euskarazko hitz bakoitzerako 2,81 analisi diferente ematen ditu. Kategoria eta azpikategoria sintaktikoa bakarrik kontuan hartuta, kasuak eta beste ezaugarri morfologikoak kontuan hartu gabe, 1,5 analisi ematen du hitz bakoitzeko, batez beste. Lematizatzailak, ordea, testuingurua aztertu ondoren, lema eta kategoria bakarra hautatzen du hitz bakoitzerako. Hanka sartzen du, baina % 1 edo % 2an baino ez. Oso tresna erabilgarria da hizkuntza-teknologian.

3.2 Ariketak

A. Analizatu Eustagger lematizatzaila erabiliz honako esaldiak:

1. Itxura hori zuen gizonak ikusi du.
2. Haurrak bizkor esan zuen etorriko zela.
3. duen, zioen, nuen, gazte, gorri, gaur, ikusten, ikus, alajaina, omen.
4. Nik huts egiten ez baldin badut, aurten ekarriko ditugu.
5. Lodia ez izateak itxuraren lerdentasuna azpimarratzen zion.
6. Nik huts egiten ez baldin badut aurten ekarriko ditugu.
7. Bart Paris hoteleko zure gela arakatu egin dute.
8. Gaur izebari omenaldia egin diote herrian.
9. *Nik iaz Parisera joan nintzen.
10. Nik iaz Parisera joateko aukera aprobetxatu egin nuen.

4 Euskararen sintaxia lantzen: AnCora, Zatiak eta Eihera

Analisi sintaktiko automatikoa ez dabil analisi morfologiko eta lematizazioa bezain zorrotz. Zaila da automatikoki lortzea esaldi baten benetako analisi sintaktikoa. Analisi sintaktikoa egiteko hainbat aukera ikusten ditu konputagailuak, baina esaldia bera ulertu gabe zaila da jakitea zein den analisi egokia. Horregatik, analisi sintaktikoa aztertzeko atal honetan, bi bide hartuko ditugu:

- *AnCora*. Euskarazko, gaztelaniako eta katalanezko corpora da, hainbat hizkuntza mailatan etiketatua. Euskarazkoari dagokionez, bertan 3.175 esaldiren analisia kontsulta daiteke. Esaldi horien analisi sintaktikoak automatikoki egin ziren, baina gero IXA taldeko hizkuntzalariek eskuz desanbiguatu zitzuten, esaldi bakoitzaren analisi egokia aukeratuz. *AnCoran* ezingo duzu edozein esaldi analizatu, zuk asmatutako edozein esaldi, alegia. Eskuz landu diren 3.175 esaldi horiek bakarrik ikusi ahal izango dituzu. Hori bai, zuhaitzak grafikoki oso erakargarria den modu batean kontsultatu ahal izango dituzu.
- *Zatiak* eta *Eihera* sintaxia lantzeko bi tresna dira. *Zatiak* esaldi bateko sintagma modukoak bereizten ditu (*chunk* edo *zati* ere esaten zaie sintagma osoak baino txikiagoak izan daitezkeen hitz-kate horiei). *Eihera*, berriz, esaldi batean agertzen diren entitateak identifikatzen ditu, baita beraien artean bereiztu ere tokia, pertsona edota erakundea adierazten dituztenak. *AnCorarekin* konparatuz, *Zatiak* eta *Eihera* tresnekin edozein esaldi azter daiteke, baita guri bururatzen zaigun edozein ere; baina noski soluzio bakarra ematen duenez, soluzio hori beti ez da egokia, tresnak automatikoki aukeratu behar izan du analisi bat nahiz eta esaldiaren esangura ez ulertu, beraz, ulergarria da beti ez asmatzea.

4.1 Ancora: esaldi analizatuak kontsultatzen

Esan bezala, AnCora euskarazko, gaztelaniazko eta katalanezko corpora da, hainbat hizkuntza-mailatan etiketatua:

* Kategoria morfologikoa

* Osagai eta funtzio sintaktikoak

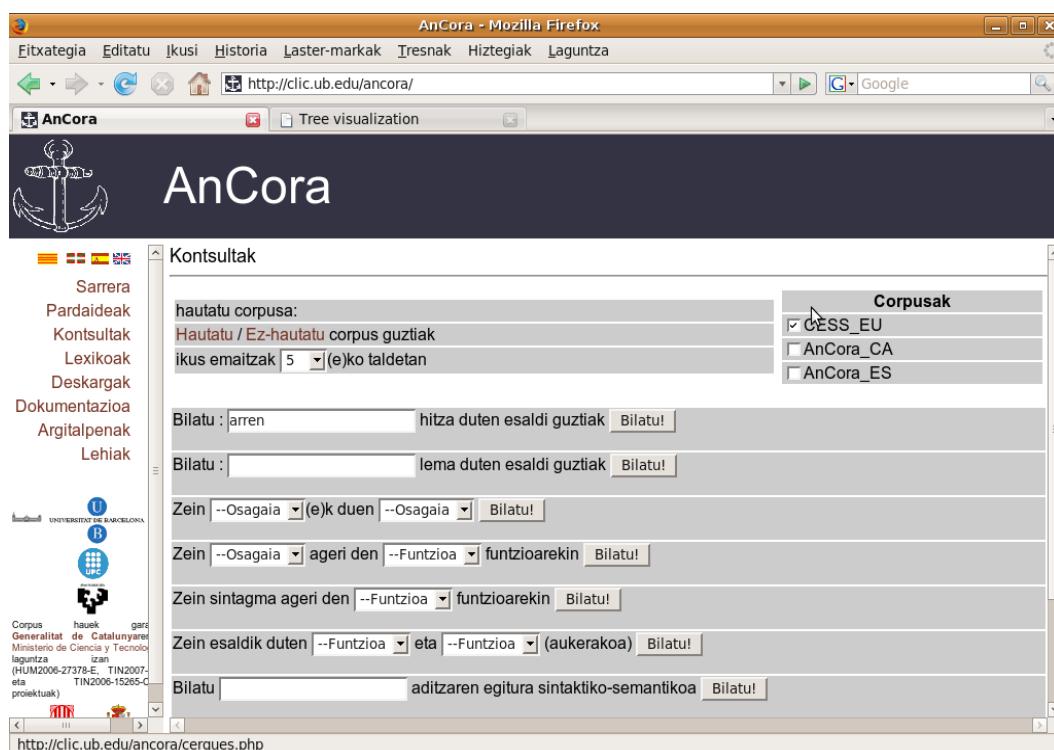
* Wordneteko adierak izenetan

* Entitateak

Gaztelaniaz eta katalanez 500.000 hitz inguru eskaintzen dira AnCora corpusean, eta euskaraz 55.000 hitz inguru. Euskarazko AnCora corpus etiketatuaren oinarria, EPEC corpora (Aduriz eta al., 2006) da. EPEC, euskararen tratamendu automatikorako erreferentzia-corpus gisa darabilgu Ixa taldean. Heren bat XX. mendeko euskararen corpus estatistikoari dagokio eta beste bi herenak Euskaldunon Egunkariari. AnCora-rako 55.000 hitz hautatu dira, CESS-ECE proiektuan garatu zen sintaktikoki etiketatutako corpusaren zati bat, eta dependentzia-eredutik osagai-eredura pasatu dira. Corpus-zati honen % 25 katalanezko eta gaztelaniazko corpusekin konparagarria da, aldi bereko berriak jasotzen baitira.

Corpus hau nola balia daitekeen ikusteko, bilatu euskarazko, katalanezko eta espanyierazko testu-corpus analizatuak konsultatzeko AnCora webgunea. Jo ezazu zuzenean helbide honetara: <http://clic.ub.edu/ancora/index.php>. Edo lehen bezala, IXA taldearen orritik (ixa.si.ehu.es) abiatuta, aukera ezazu *Demoak* ezkerreko menuan eta bertan aukeratu “[Ancora: zuhaitz sintaktikoen bankua](#)”.

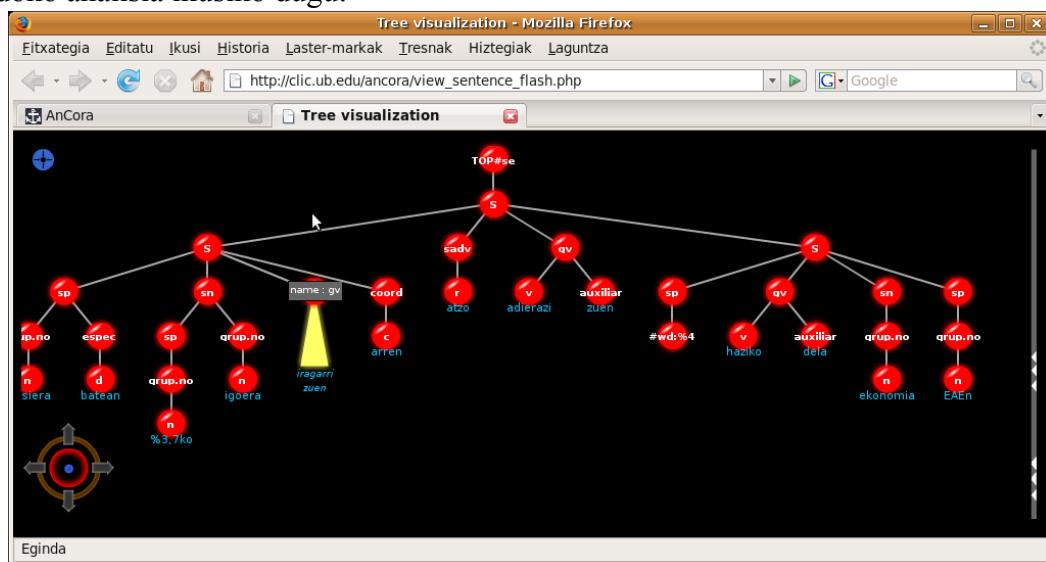
Ancora zerbitzuaren hasierako web-orrian aurkezpena eta hainbat datu ematen dira. Ezkerreko menuko Konsulta aukeratuz honako pantaila batera pasatuko gara:



Hor, eskuinaldean, goian CESS_EU corpusa aukeratuko dugu eta gero nahi dugun esaldia bilatu beharko dugu. Pantaila horretako adibidean, “*arren*” hitza duten esaldiak bilatzeko eskatu da. Ondoko pantaila azalduko da gero bilaketaren emaitzak aurkezteko:

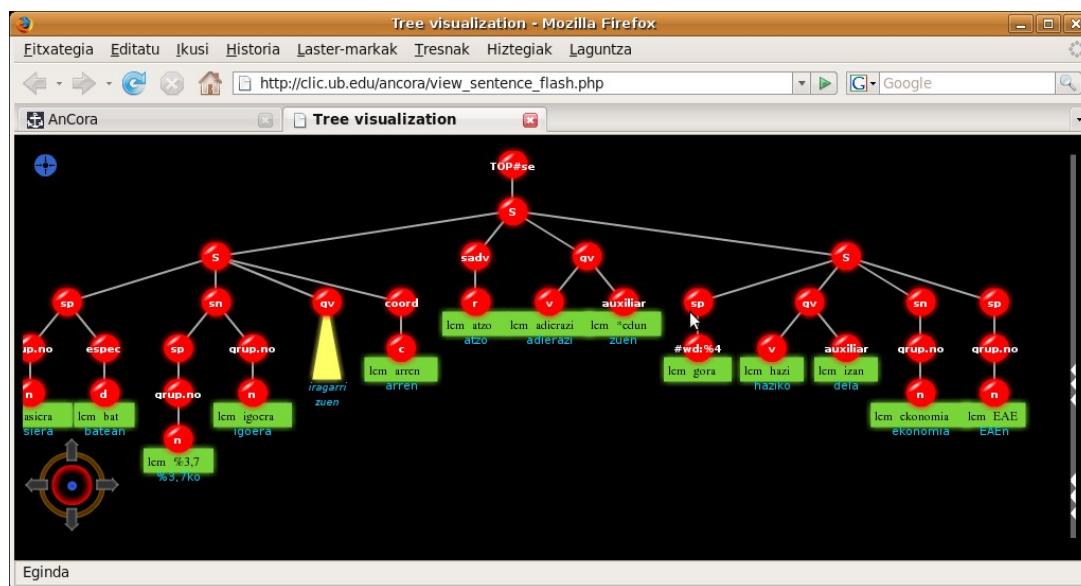
The screenshot shows the AnCora interface in Mozilla Firefox. The main window displays search results for the word 'arren'. On the left, there's a sidebar with links like 'Kontsultak', 'Corpusa', 'Matches', and 'Info'. The main content area has two tabs: 'Ekintzak' and 'Zuhaitza'. The 'Zuhaitza' tab is active, showing a text snippet: 'hasiera batean %3,7ko igoera iragarri zuen arren atzo adierazi zuen haziko dela ekonomia EAEn'. Below this, there are three options: 'Ikus zuhaitz osoa (grafikoa)', 'Ikus zuhaitz osoa (hierarkikoa)', and 'Ikus esaldi osoa (testua)'. The bottom part of the interface shows the corpus information: 'CESS_EU sent3@egun.06-1-p0002200.2000-06-01.economia top'. There are also logos for the University of Barcelona and other institutions.

Demagun aztertu nahi dugula lehenengo esaldiaren analisia (“*Hasiera batean %3,7ko igoera iragarri zuen arren atzo adierazi zuen haziko dela ekonomia EAEn*”) bere ezkerrean dagoen botoien artean “*ikus zuhaitz osoa (grafikoa)*” aukeratuz gero ondoko analisia ikusiko dugu:



Orain hainbat aukera ditugu zuhaitz horretan dagoen informazioa hobeto ikusteko. Aukera praktikoenak hauek dira:

- Nodo batean klikatuz gero bere azpian dagoen adar osoa trinkotu egingo da. Aurreko irudiko zuhaitzean horrela egin da “*iragarri zuen*” hitzen adarraren irudia trinkotuz.
- Nodo bakoitzean zer ezaugarri erakutsi behar den zehatz dezakegu eskuinean azaltzen diren menuak erabiliz. Ondoko irudian ikus daiteke nola erakusten den zuhaitza nodo guztien lema aurkezteko eskatuz gero.

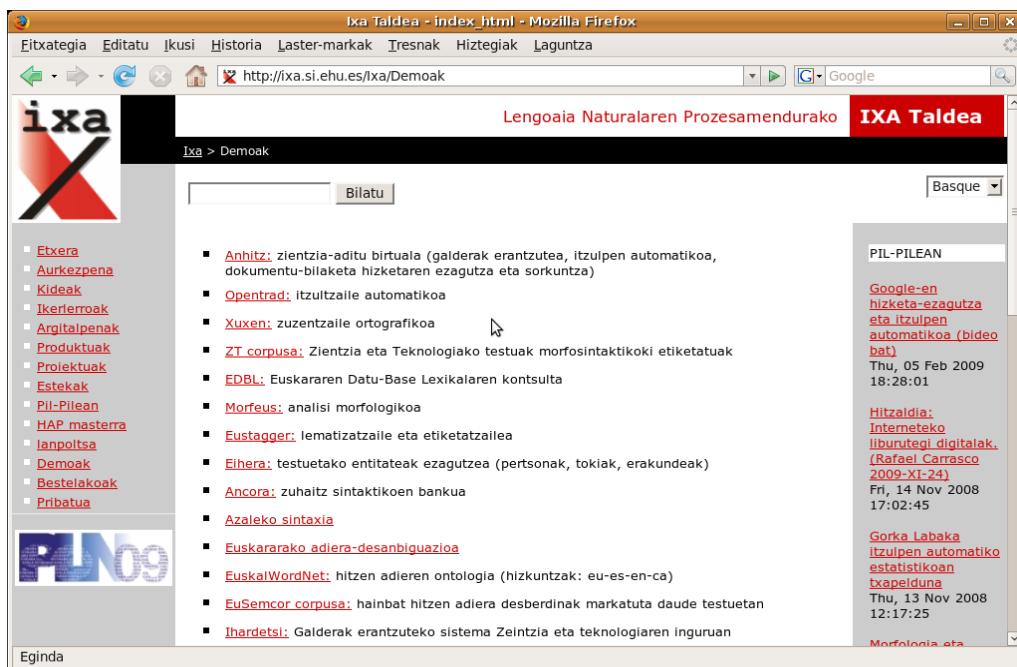


4.2 Ariketa:

- A. Bilatu itzazu Ancoran esaldi hauen analisia, eta konpara itzazu emaitzak Morfeus eta Eustagger-ek ematen dituzten analisiekin.
1. Lodia ez izateak itxuraren lerduntasuna azpimarratzen zion.
 2. Nik hutsegiten ez baldin badut aurten ekarriko ditugu.
 3. Bart Paris hoteleko zure gela arakatu egin dute.

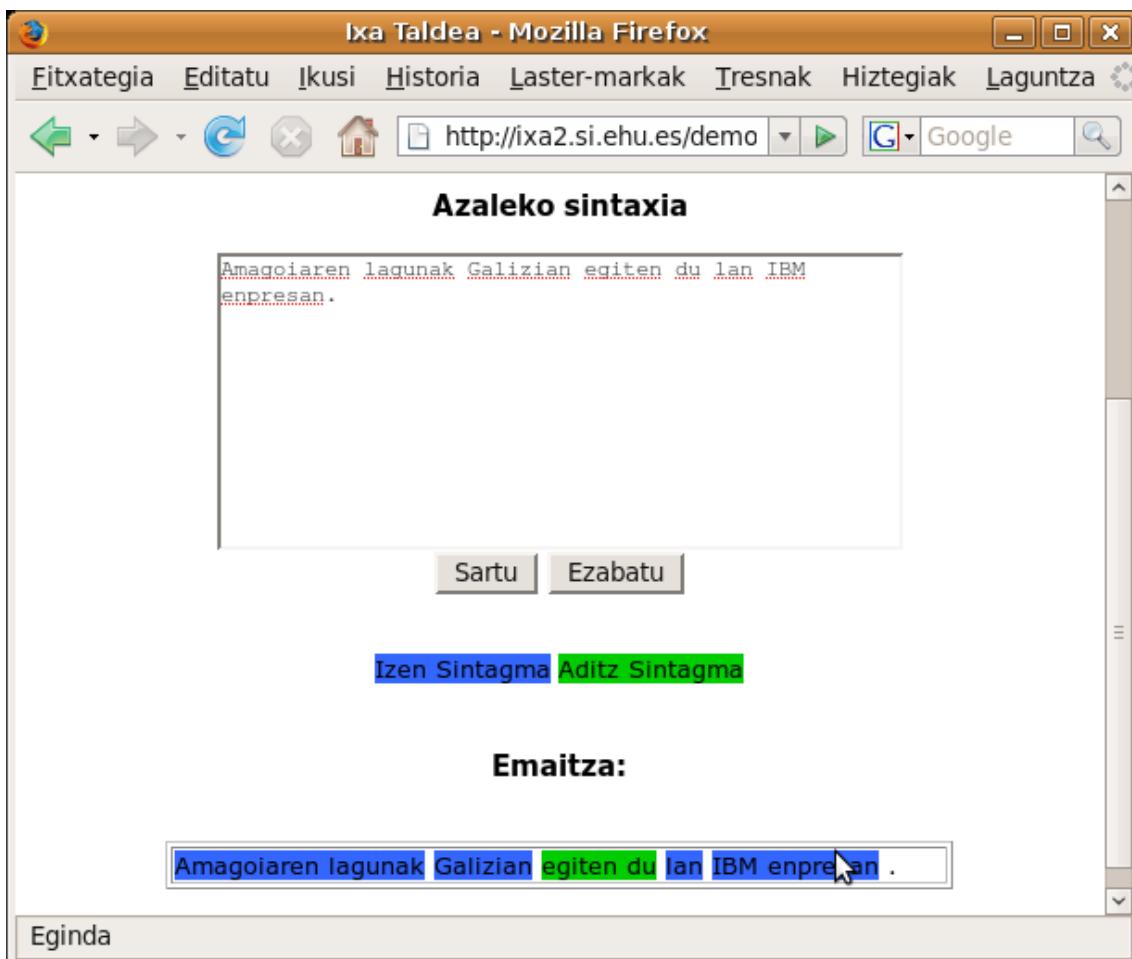
4.3 Zatiak (azaleko sintaxia) eta Eihera (entitateak) sintaxi-tresnak

Zatiak eta Eihera sintaxia lantzeko bi tresna dira. Tresna horiek erabiltzeko nahikoa da IXA taldeko demoen web-orrira joatea eta [Azaleko sintaxia](#) edo [Eihera: esteketan klikatzea](#).



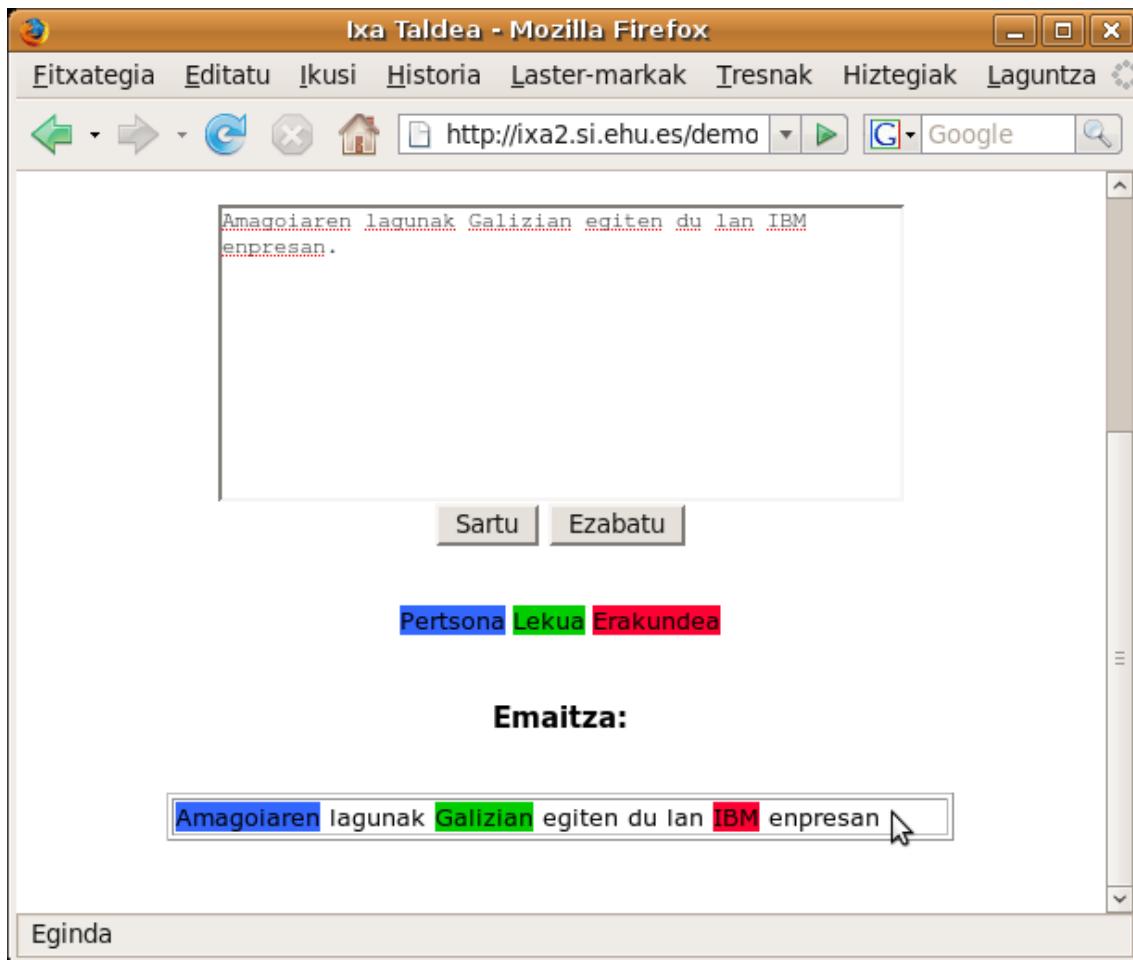
Zatiak programak esaldi bateko sintagma modukoak bereizten ditu. *Chunk* edo *zati* ere esaten zaie sintagma osoak baino txikiagoak izan daitezkeen hitz-kate horiei. Analisi sintaktiko osoa ez da lortzen horrela, zati horien arteko harremana ez baita zehazten. Azaleko sintaxia edo sintaxi partzial (shallow parsing) deritzogu analisi mota honi.

Azaleko sintaxia demoaren orrian zaudela, idatz ezazu “*Amagoiaren lagunak Galizian egiten du lan IBM enpresan*” eta sakatu *Sartu* botoia. Honako leiho bat zabalduko da esaldi bat osatzen duten sintagma edo kate sintaktiko guziekin:



Azterturiko esaldi horretan, urdinez adierazi dira esaldiko sintagmak (<*Amagoiaren lagunak*>, <*Galizian*>, <*lan*> eta <*IBM enpresan*>) eta berdez aditz sintagma (<*egiten du*>). Zehatz-mehatz hitz eginda horiek denak ez dira izen-sintagmak, <*Galizian*> eta <*IBM enpresan*> preposizio-sintagma direla esan beharko litzateke, baina zentzu orokor batean hartuta horiek ere izen sintagma gisa hartzen ditu *Zatiak* programak.

Eihera tresnak, berri, esaldi batean agertzen diren entitateak (pertsonak, tokiak, erakundeak) identifikatzen ditu. Iku dezagun, bada, nola egiten duen lan. Behin *Eiheran* zaudela, idatz ezazu aurreko esaldi bera, “*Amagoiaren lagunak Galizian egiten du lan IBM enpresan*”, eta sakatu *Sartu* botoia. Honako leihotz bat zabalduko da zeinetan entitateak kolore desberdinez markatuak agertuko diren: urdinez, pertsona-izenak (<*Amagoiaren*>); berdez, leku-izenak(<*Galizian*>); eta gorriz, erakunde-izenak (<*IBM*>).



4.4 Ariketa

- A. Bereizi sintagmak ondoko esaldietan Zatiak tresna erabiliz:
1. Hondarribiako arrantzaleak kofradian bildu ziren atzo.
 2. Peru baserriko amonarengana joan da.
 3. Gazte horien esamesak ez dira niretzat oso fidagarriak.
 4. Gezur hori esan zenien lagunei hementxe bertan gure aurrean.
 5. Haurraren jostailu berri hauek egurrezkoak dira.

6. Ikastolan, ikasleek astero hainbat gai desberdini buruzko azalpenak egiten dituzte.
7. Su handiak urrutiko mundu magiko batera eramango zaitu.
8. Azterketari zaila izango zelako susmoa hartu genion.

B. Identifikatu entitateak ondoko esaldietan Eihera tresna erabiliz:

1. Hondarribiako arrantzaleak kofradian bildu ziren atzo.
2. Peru baserriko amonarengana joan da.
3. 1952.eko maiatzean Luis Villasante Kortabitarte jaunak bere sarrera-hitzaldia egin zuen Bizkaiko Diputazioaren Jauregian.
4. Gu Gorbea aldeko bazter guztietatik ibiliak gara.
5. NASAk abenduaren 28an aireratu zuen globo batek 42 egun baino gehiago egin ditu Antartika gainean.

5 Euskararako beste tresna linguistiko batzuk

Morpheus-en analisi osoak

ZT Corporusa

<http://www.ztcorpusa.net/>

EDBL datu base lexikalaren kontsulta

<http://ixa2.si.ehu.es/demo/edbl.jsp>

Entitateak

<http://ixa2.si.ehu.es/demo/entitateak.jsp>

Euskararako adiera desanbiguazioa

<http://ixa3.si.ehu.es/wsd-demo/>

EuskalWordNet-en kontsularako interfazea

<http://ixa2.si.ehu.es/mcr/wei.html>

EuSemcor-ren kontsultarako interfazea

<http://sisx04.si.ehu.es:8080/eusemcor/>

Opentrad itzultzalea <http://www.opentrad.org/demo/?language=eu>

6 Gaztelania lantzen: Freeling eta Ancora.

6.1 Kategoria multzoa

Freeling-ek eta Ancora sistemek erabiltzen dituzten kategoriak PAROLE multzokoak dira, EAGLES taldeak definitu zuen bera. Freeling sistemaren web orrian ere ikus daiteke kategoria horien azalpen zabala *Documentation* atalean, konkretuki beste web orri honetan:

<http://garraf.epsevg.upc.es/freeling/doc/userman/parole-es.html>

Parole etiketek sistema desberdin bat jarraitzen dute. Adibidez, *chico* hitzaren etiketa hau da: NCMS000; non NCMS letrek adierazten duten izen arrunta maskulino singular dela (NCMS: NombreComúnMasculinoSingular). Kategoria nagusi bakoitzaren ezaugarrien balioak letra-kode bereziekin adierazten dira; esaterako izenetan maskulino eta singular ezaugarria M eta S letrekin 3. eta 4. posizioetan. Kategoria nagusiak hauek dira:

- adjetivos (A)
- adverbios (R)
- artículos (T)
- determinantes (D)
- nombres (N)
- verbos (V)
- pronombres (P)
- conjunciones (C)
- interjecciones (I)
- preposiciones (S)
- signos de puntuación (F)
- numerales (Z)
- fechas y horas (W)

Gero kategoria nagusi horietako bakoitzak bere kode bereziak ditu ezaugarrien balioak adierazteko. Adibidez, izenentzako ezaugarriak, balioak eta kodeak honako hauek dira:

NOMBRES

Pos.	Ezaugarria	Balioa	Kodea
1	Categoría	Nombre	N
2	Tipo	Común	C
		Propio	P
3	Género	Masculino	M
		Femenino	F
		Común	C
4	Número	Singular	S
		Plural	P
		Invariable	N
5	Caso	-	0

6	Género Semántico -	0
7	Grado Apreciativo	A

Aditzenak, aldiz, hauek dira:

ADITZAK/ VERBOS

Pos.	Ezaugarria	Balioa	Kodea
1	Categoría	Verbo	V
2	Tipo	Principal	M
		Auxiliar	A
3	Modo	Indicativo	I
		Subjuntivo	S
		Imperativo	M
		Condicional	C
		Infinitivo	N
		Gerundio	G
		Participio	P
4	Tiempo	Presente	P
		Imperfecto	I
		Futuro	F
		Pasado	S
5	Persona	Primera	1
		Segunda	2
		Tercera	3
6	Número	Singular	S
		Plural	P
7	Género	Masculino	M
		Femenino	F

6.2 Ariketa:

A. Ondoko zutabeak aztertu eta lotu hitz bakoitza bere etiketarekin, nahastuta daude:

cantas	NP000G0
éramos	NCMS00D
cantadas	NCMN000
cantarías	VMIC2S0
Barcelona	VMP00PF
gatito	VMIP2S0
cortapapeles	VSII1P0

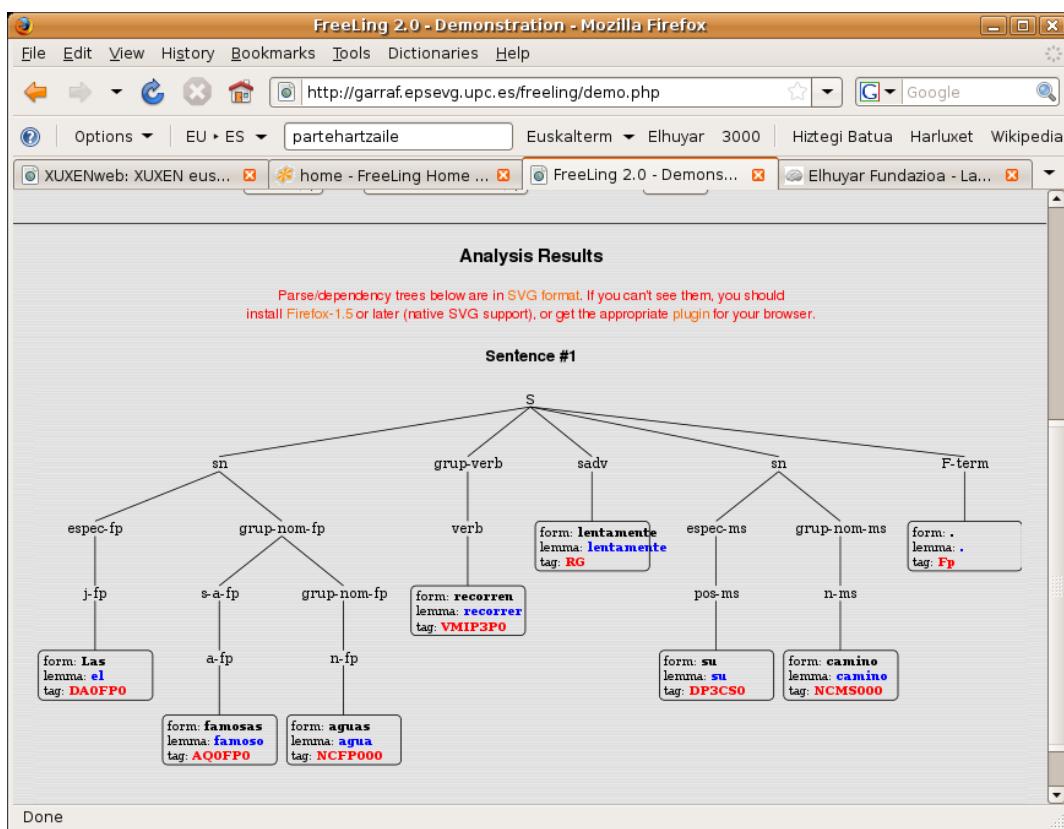
6.3 Freeling

Bilatu “Freeling” analizatzailea Interneten eta ezkerreko menuan aukeratu “online demo” sistema zuzenean nola dabilen ikusi ahal izateko. Helbide honetara ailegatuko zara: <http://garraf.epsevg.upc.es/freeling/demo.php>

Hor zaudela aukeratu “Shallow parsing” (azaleko analisia) “select output” kutxan, eta analiza ezazu honako perpausa: “*Las famosas aguas recorren lentamente su camino.*”

The screenshot shows the FreeLing 2.1 demo interface. At the top, there's a navigation bar with links like Itxategia, Editatu, Ikusi, Historia, Laster-markak, Tresnak, Hiztegiak, and Laguntza. Below that is a browser-like header with back, forward, search, and Google links. A sidebar on the left shows language selection (Aukerak, ES-EU) and Euskalterm (Elhuyar 3000). The main content area has a title "FreeLing 2.1" and subtitle "AN OPEN-SOURCE SUITE OF LANGUAGE ANALYZERS". On the left, a text input field says "Write your sentences" and contains the sentence "Las famosas aguas recorren lentamente su camino.". To the right, under "Analysis options", several checkboxes are checked: Multiword detection, Number recognition, Date/Time recognition, Quantities, ratios, and percentages, and Named Entity detection. Other options like Named Entity classification, No sense annotation (selected), WN sense annotation: All senses, and WN sense annotation: Most frequent sense are also shown. Below these are "Select language" (Spanish selected) and "Select output" dropdown menus. The "Select output" menu is open, showing "Shallow Parsing" (selected), "Morphological Analysis" (highlighted in yellow), PoS Tagging, Shallow Parsing, and Dependency Parsing. At the bottom, there's a "Submit" button and a link "Eginda".

Honako emaitza hau lortuko duzu:



Orain “select output” kutxan aukera ezazu “POS tagging” (etiketatu kategoriekin) “Shallow parsing” (azaleko analisia) izan ordez. Emaitzan hitz soilak ikusiko dituzu, ez zuhaitzik eta hitz bakotzarekin bere kategoria:

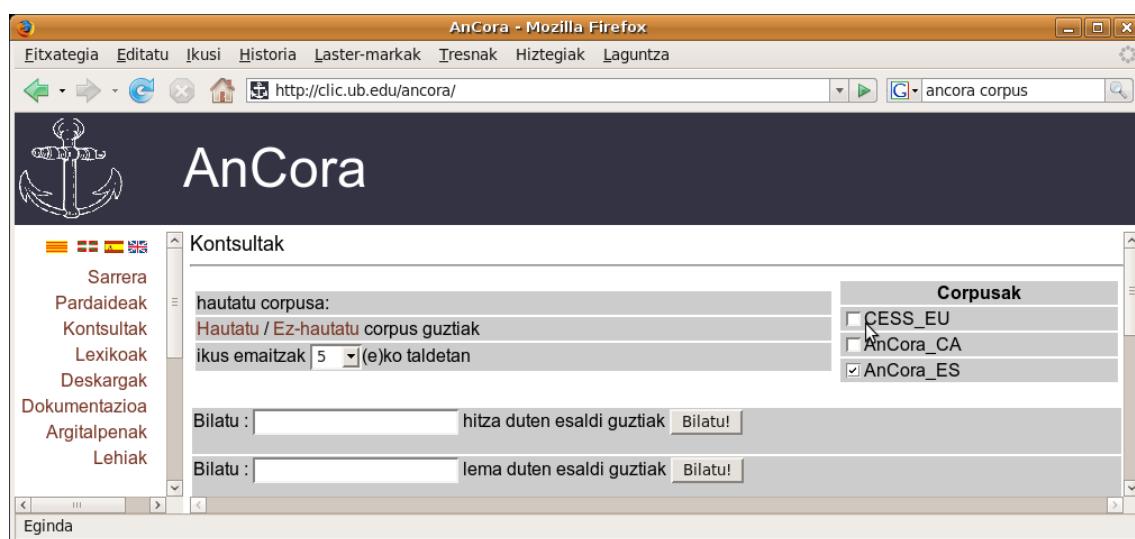
The screenshot shows the FreeLing 2.0 demonstration interface. On the left, there is a text input field labeled "Write your sentences" containing the sentence "Las famosas aguas recorren lentamente su camino.". To the right of the text input is a section titled "Analysis options" with several checkboxes and radio buttons. The checked options include: Multiword detection, Number recognition, Date/Time recognition, Quantities, ratios, and percentages, Named Entity detection, and No sense annotation. The radio buttons for WN sense annotation are set to "All senses". Below these settings are dropdown menus for "Select language" (Spanish) and "Select output" (PoS Tagging), and a "Submit" button. The main area is titled "Analysis Results" and shows the sentence "Sentence #1" followed by a table of tokens and their PoS tags. The tokens and their tags are: Las (el, DA0FP0), famosas (famoso, AQ0FP0), aguas (agua, NCFP000), recorren (recorrer, VMIP3P0), lentamente (RG, RG), su (su, DP3CS0), camino (camino, NCMS000), and . (., Fp).

6.4 Ancora

AnCora euskarazko, gaztelaniazko eta katalanezko corpusa da, hainbat hizkuntza-mailatan etiketatua. Beraz espainierazko perpausen analisi sintaktikoak ere ikus ditzakegu; bere erabilera euskararako definitu dugun erabilera bera da.

Beraz, besterik gabe jo ezazu zuzenean helbide honetara: <http://clic.ub.edu/ancora/index.php>. Edo lehen bezala, “IXA taldearen orritik(ixa.si.ehu.es) abiatuta, aukera ezazu *Demoak* ezkerreko menuan eta bertan aukeratu “Ancora: zuhaitz sintaktikoen bankua”. Aldaketa bakarra da hasierako orrian goian eskuinaldean aztertu nahi den corpusa aukeratu behar dela: CESS_EU euskarazko esaldiak aztertzeko, AnCora_CA katalanerako eta AnCora_ES espainierarako.

Espainierazko esaldiak analizatzeko beraz AnCora_ES corpusa aukeratu bilatu aztertu nahi duzun esaldia eta ikus ezazu bere analisia modu grafikoan ala testu gisa.



7 Ingelesa lantzen.

Freeing eta Conexor.

7.1 Kategoria multzoa.

Ingeleserako gehien erabiltzen den kategoria multzoa *Penn Treebank*-a osatzeko erabili zena da. Etiketa honen erreferentzia eta azalpen nagusia Beatriz Santorini-ren artikulua¹ izan daiteke edo sarean aurki daitezkeen beste webgune batzuk ere². Hemen aurkezten ditugu hitz mailan etiketatzeko erabiltzen diren etiketak, etiketa guztiak eranskinetan ikus daitezke.

- CC - Coordinating conjunction
- CD - Cardinal number
- DT - Determiner
- EX - Existential there
- FW - Foreign word
- IN - Preposition or subordinating conjunction
- JJ - Adjective
- JJR - Adjective, comparative
- JJS - Adjective, superlative
- LS - List item marker
- MD - Modal
- NN - Noun, singular or mass
- NNS - Noun, plural
- NNP - Proper noun, singular
- NNPS - Proper noun, plural
- PDT - Predeterminer
- POS - Possessive ending
- PRP - Personal pronoun
- PRP\$ - Possessive pronoun (prolog version PRP-S)
- RB - Adverb
- RBR - Adverb, comparative
- RBS - Adverb, superlative
- RP - Particle
- SYM - Symbol
- TO - to
- UH - Interjection
- VB - Verb, base form
- VBD - Verb, past tense
- VBG - Verb, gerund or present participle
- VBN - Verb, past participle
- VBP - Verb, non-3rd person singular present
- VBZ - Verb, 3rd person singular present
- WDT - Wh-determiner
- WP - Wh-pronoun

¹ <http://www.ims.uni-stuttgart.de/projekte/corplex/TreeTagger/Penn-Treebank-Tagset.ps>

² <http://www.ims.uni-stuttgart.de/projekte/CorpusWorkbench/CQP-HTMLDemo/PennTreebankTS.html>

WP\$ - Possessive wh-pronoun (prolog version WP-S)
WRB – Wh-adverb

7.2 Freeling

Freeling analizatzaile sintaktikoa lau hizkuntzatan erabil daiteke: espainiera, katalana, galiziera, ingelesa eta italiara. Beraz, espainierarako erakutsi dugun bezalaxe erabil daiteke ingeleserako ere, Nahikoa da hizkuntza aukeratzea beheko *Select Language* kutxan irudi honetan ikusten den bezala:

Ondoko irudi honetan ikus daiteke zer ematen digun POS_tagging aukeratuta (hitz bakoitzerako bere lema eta kategoria desanbiguatua). Lortu liteke zuhaitz osoa ere *Shallow parsing* aukera erabiliz.

Officials	fear	that	a	growing	number	of	women	are	using	illegal	silicone	injections	instead_of
official	fear	that	I	grow	number	of	woman	be	use	illegal	silicone	injection	instead_of
NNS	VBP	IN	Z	VBG	NN	IN	NNS	VBP	VBG	JJ	NN	NNS	IN

8 Bibliografia

Oinarrizko bibliografia

- Aduriz i., Aranzabe M.J., Arriola J.M. eta Díaz de Ilarraz A. 2006 **Sintaxi partziala.** In B. Fernández eta I. Laka (arg.) *Andolin gogoan: Essays in Honour of Professor Eguzkitza*. UPV/EHUko Argitarapen Zerbitzua, Bilbo.
- Aduriz I. eta Díaz de Ilarraz A. 2003 **Morphosyntactic disambiguation and shallow parsing in Computational Processing of Basque.** In B. Oyharcabal (arg.), *Inquiries into the lexicon-syntax relations in Basque*. ASJUren gehigarria. UPV/EHU, Bilbo.
- Aldezzabal I., Arriola J., Díaz de Ilarraz A., Sarasola K. 2005
Hizkuntzalaritza Konputazioanala
Liburuaren ISBN: 84-8438-065-3. HIZTEK saila. Udako Euskal Unibertsitatea
- Alegria I., Miriam Urkia 2002
Morfología Konputazioanala. Euskararen morfologiaren deskribapena.
UEU. ISBN: 84-8438-034-3
- Alegria i., Balza I., Ezeiza N., Fernández I., Urizar R. 2003 **Named Entity Recognition and Classification for texts in Basque.** II Jornadas de Tratamiento y Recuperación de Infomación. Madrid.
- Alegria I., Artola X., Díaz de Ilarraz A., Sarasola K. 2008
Hizkuntza-teknologia Ixa taldean, euskararen erabilera errazteko eta sustatzeko aplikazioak
Bat Soziolinguistica. 66. zenb. 41-60 orr. ISSN:1130-8435
- Ezeiza N. 1997. **EUSLEM, euskararako lematizatzaile/etiketatzaile baten diseinua eta implementazioa.** Tesina, Euskal Herriko Unibertsitatea
- Freeling. User manual. <http://garraf.epsevg.upc.es/freeling/doc/userman/parole-es.pdf>
- Freeling. Introducción a las etiquetas EAGLES (v 2.0)
<http://garraf.epsevg.upc.es/freeling/doc/userman/parole-es.html#cifras>
- Martí M.A., Taulé M., Bertran M., Márquez L. **AnCorA: Multilingual and Multilevel Annotated Corpora**
- Santorini`B. **Part-of-Speech Tagging Guidelines for the Penn Treebank Project.**
<http://www.ims.uni-stuttgart.de/projekte/corplex/TreeTagger/Penn-Treebank-Tagset.ps>

Bestelako bibliografia

- Aduriz I., Aranzabe M.J., Arriola J.M., Atutxa A., Díaz de Ilarraz A., Ezeiza N., Gojenola K., Oronoz M., Soroa A., Urizar R. 2006 **Methodology and steps towards the construction of EPEC, a corpus of written Basque tagged at morphological and syntactic levels for the automatic processing.** In Wilson A., Rayson P. eta Archer D. (arg.), *Corpus Linguistics Around the World*, 1-15. Rodopi (Netherland).
- Alegria I., Aranzabe M., Ezeiza A., Ezeiza N., Urizar R. 2002
Robustness and customisation in an analyser/lemmatiser for Basque
LREC-2002 Customizing knowledge in NLP applications workshop, pages 1-6, Las Palmas de Gran Canaria, 28th May 2002
- Palomar M., Civit M., Díaz de Ilarraz A., Moreno L., Bisbal E., Aranzabe M.J., Ageno A., Martí M.A., Navarro B. **3LB: Construcción de una base de datos de árboles sintáctico-semánticos para el catalán, euskera y castellano.** XX Congreso de la Sociedad Española para el Procesamiento del Lenguaje Natural (SEPLN), 81-88. Universidad de Barcelona, Barcelona.

9 Eranskinak

9.1 Euskararen kategoria multzoa

Kategoria Lexikalak (15)

Kategoria Nagusiak eta Azpikategoriak

- IZE izenak

ARR	arruntak (<i>zuhaitz</i>)
IZB	pertsona-izen bereziak (<i>Mikel</i>)
LIB	leku-izen bereziak (<i>Donostia</i>)
ZKI	zenbakia (<i>bat</i>)
- ADJ adjektiboak

ARR	arruntak (<i>handi, benetako</i>)
GAL	galdeztzaileak (<i>nongo</i>)
- ADI aditzak

SIN	sinpleak (<i>ekarri</i>)
ADK	konposatuak (<i>lo egin</i>)
ADP	perifrastikoak (<i>ahal izan</i>)
FAK	faktitiboak (<i>etorrarazi</i>)
- ADB adberbioak

ARR	arruntak (<i>gaur, negarrez</i>)
GAL	galdeztzaileak (<i>noiz</i>)
- DET determinatzaileak

ERK	erakusleak
ERK	ARR arruntak (<i>hau</i>)
ERKIND	indartuak (<i>berori</i>)
NOL	nolakotzaileak
NOLARR	arruntak (<i>edozein</i>)
NOLGAL	galdeztzaileak (<i>zein</i>)
ZNB	zenbatzaileak
DZH	zehaztuak (<i>bi</i>)
BAN	banatztaileak (<i>bina</i>)
ORD	ordinalak (<i>bigarren</i>)
DZG	zehaztugabeak (<i>zenbait</i>)
ORO	orokorrak (<i>guzti</i>)
- IOR izenordainak

PER	pertsonalak
PERARR	arruntak (<i>ni</i>)
PERIND	indartuak (<i>neu</i>)
IZG	zehaztugabeak
IZGMGB	mugagabeak (<i>norbait</i>)
IZGGAL	galdeztzaileak (<i>nor</i>)
BIH	bihurkariak (<i>-(r)en burua</i>)
ELK	elkarkariak (<i>elkar</i>)

- LOT loturazkoak
LOK lokailuak (*hala ere*)
JNT juntagailuak (*edo*)
- PRT partikulak (*omen, ote, ...*)
- ITJ interjekzioak (*alajaina!*)
- BST bestelakok (*baldin*)

Kategoria lagungarriak (5)

- ADL ADITZ LAGUNTZAILEAK (*du*)
- ADT ADITZ SINTETIKOAK (*dator*)
- SIG SIGLAK (*EHU*)
- SNB SINBOLOAK (*km, cm, g, ...*)
- LAB LABURDURAK (*etab.*)

Kategoria Morfologikoak (9)

- AMM ADITZ-MOTA MORFEMAK (*-tu, -t(z)e, ...*)
- ASP ASPEKTU-MORFEMAK (\emptyset , *-ko, ...*)
- ATZ ATZIZKIAK (*-pe*)
- AUR AURRIZKIAK (*ber-*)
- DEK DEKLINABIDE MORFEMAK (*-aren*)
- ELI ELIPSIA (\emptyset)
- ERL ERLAZIO ATZIZKIAK (*-(e)la*)
- GRA GRADUATZAILEAK (*-ago*)
- MAR MARRA (-)

Puntuazio-zeinuak (3)

- PNT PUNTUA
- BPM BESTE PUNTUAZIO ZEINUAK (*puntuaren pareko izan daitezkeenak*)
- PSB PUNTUAZIO SINBOLOAK (*parentesiak, marra luzea, kakotxak, ...*)

9.2 Gaztelaniaren kategoria multzoa

Parole etiketa multzoa EAGLES taldeak definitu zuen. Freeling sistemaren web orrian ere ikus daiteke kategoria horien azalpen zabala *Documentation* atalean³. Hauek dira kategoria nagusien kode bereziak ezaugarrrien balioak adierazteko.

ADJETIVOS

Pos.	Atributo	Valor	Código
1	Categoría	Adjetivo	A
2	Tipo	Calificativo	Q
3	Grado	Apreciativo	A
4	Género	Masculino	M
		Femenino	F
		Común	C
5		Número	Singular Plural Invariable
6	Caso	-	0
7	Función	Participio	P

ADVERBIOS

Pos.	Atributo	Valor	Código
1	Categoría	Adverbio	R
2	Tipo	General	G

ARTÍCULOS

Pos.	Atributo	Valor	Código
1	Categoría	Artículo	T
2	Tipo	Definido	D
3	Género	Masculino	M
		Femenino	F
		Común	C
4	Número	Singular	S
		Plural	P
5	Caso	-	0

DETERMINANTES

Pos.	Atributo	Valor	Código
1	Categoría	Determinante	D
2	Tipo	Demostrativo	D
		Posesivo	P
		Interrogativo	T
		Exclamativo	E
		Indefinido	I
3	Persona	Primera	1
		Segunda	2

³<http://garraf.epsevg.upc.es/freeling/doc/userman/parole-es.html>

		Tercera	3
4	Género	Masculino	M
		Femenino	F
		Común	C
5	Número	Singular	S
		Plural	P
		Invariable	N
6	Caso	-	0
7	Poseedor	1 ^a persona-sg	1
		2 ^a persona-sg	2
		3 ^a persona	0
		1 ^a persona-pl	4
		2 ^a persona-pl	5

NOMBRES

Pos.	Atributo	Valor	Código
1	Categoría	Nombre	N
2	Tipo	Común	C
		Propio	P
3	Género	Masculino	M
		Femenino	F
		Común	C
4	Número	Singular	S
		Plural	P
		Invariable	N
5	Caso	-	0
6	Género Semántico	-	0
7	Grado	Apreciativo	A

VERBOS

Pos.	Atributo	Valor	Código
1	Categoría	Verbo	V
2	Tipo	Principal	M
		Auxiliar	A
3	Modo	Indicativo	I
		Subjuntivo	S
		Imperativo	M
		Condicional	C
		Infinitivo	N
		Gerundio	G
		Participio	P
4	Tiempo	Presente	P
		Imperfecto	I
		Futuro	F
		Pasado	S
5	Persona	Primera	1
		Segunda	2
		Tercera	3
6	Número	Singular	S
		Plural	P

7	Género	Masculino	M
		Femenino	F

PRONOMBRES

Pos.	Atributo	Valor	Código
1	Categoría	Pronombre	P
2	Tipo	Personal	P
		Demostrativo	D
		Posesivo	X
		Indefinido	I
		Interrogativo	T
		Relativo	R
3	Persona	Primera	1
		Segunda	2
		Tercera	3
4	Género	Masculino	M
		Femenino	F
		Común	C
5	Número	Singular	S
		Plural	P
		Invariable	N
6	Caso	Nominativo	N
		Acusativo	A
	Dativo	D	
		Oblicuo	O
7	Poseedor	1 ^a persona-sg	1
		2 ^a persona-sg	2
		3 ^a persona	0
		1 ^a persona-pl	4
		2 ^a persona-pl	5
8	Politeness	Polite	P

CONJUNCIONES

Pos.	Atributo	Valor	Código
1	Categoría	Conjunción	C
2	Tipo	Coordinada	C
		Subordinada	S
3	-	-	0
4	-	-	0

NUMERALES

Pos.	Atributo	Valor	Código
1	Categoría	Numeral	M
2	Tipo	Cardinal	C
		Ordinal	O
3	Género	Masculino	M
		Femenino	F
		Común	C
4	Número	Singular	S
		Plural	P

5	Caso	-	0
6	Función	Pronominal	P
		Determinante	D
		Adjetivo	A

INTERJECCIONES

Pos.	Atributo	Valor	Código
1	Categoría	Interjección	I

ABREVIATURAS

Pos.	Atributo	Valor	Código
1	Categoría	Abreviatura	Y

PREPOSICIONES

Pos.	Atributo	Valor	Código
1	Categoría	Adposición	S
2	Tipo	Preposición	P
3	Forma	Simple	S
		Contraída	C
3	Género	Masculino	M
4	Número	Singular	S

SIGNOS DE PUNTUACIÓN

Pos.	Atributo	Valor	Código
1	Categoría	Puntuación	F

9.3 Ingelesaren kategoria multzoa

9.3.1 Clause Level

- S - simple declarative clause, i.e. one that is not introduced by a (possibly empty) subordinating conjunction or a wh-word and that does not exhibit subject-verb inversion.
- SBAR - Clause introduced by a (possibly empty) subordinating conjunction.
- SBARQ - Direct question introduced by a wh-word or a wh-phrase. Indirect questions and relative clauses should be bracketed as SBAR, not SBARQ.
- SINV - Inverted declarative sentence, i.e. one in which the subject follows the tensed verb or modal.
- SQ - Inverted yes/no question, or main clause of a wh-question, following the wh-phrase in SBARQ.

9.3.2 Phrase Level

- ADJP - Adjective Phrase.
- ADVP - Adverb Phrase.
- CONJP - Conjunction Phrase.
- FRAG - Fragment.
- INTJ - Interjection. Corresponds approximately to the part-of-speech tag UH.
- LST - List marker. Includes surrounding punctuation.
- NAC - Not a Constituent; used to show the scope of certain prenominal modifiers within an NP.
- NP - Noun Phrase.
- NX - Used within certain complex NPs to mark the head of the NP. Corresponds very roughly to N-bar level but used quite differently.
- PP - Prepositional Phrase.
- PRN - Parenthetical.
- PRT - Particle. Category for words that should be tagged RP.
- QP - Quantifier Phrase (i.e. complex measure/amount phrase); used within NP.
- RRC - Reduced Relative Clause.
- UCP - Unlike Coordinated Phrase.
- P - Verb Phrase.
- WHADJP - Wh-adjective Phrase. Adjectival phrase containing a wh-adverb, as in how hot.
- WHAVP - Wh-adverb Phrase. Introduces a clause with an NP gap. May be null (containing the 0 complementizer) or lexical, containing a wh-adverb such as how or why.
- WHNP - Wh-noun Phrase. Introduces a clause with an NP gap. May be null (containing the 0 complementizer) or lexical, containing some wh-word, e.g. who, which book, whose daughter, none of which, or how many leopards.
- WHPP - Wh-prepositional Phrase. Prepositional phrase containing a wh-noun phrase (such as of which or by whose authority) that either introduces a PP gap or is contained by a WHNP.

X - Unknown, uncertain, or unbracketable. X is often used for bracketing typos and in bracketing the...the-constructions.

9.3.3 Word level

CC - Coordinating conjunction
 CD - Cardinal number
 DT - Determiner
 EX - Existential there
 FW - Foreign word
 IN - Preposition or subordinating conjunction
 JJ - Adjective
 JJR - Adjective, comparative
 JJS - Adjective, superlative
 LS - List item marker
 MD - Modal
 NN - Noun, singular or mass
 NNS - Noun, plural
 NNP - Proper noun, singular
 NNPS - Proper noun, plural
 PDT - Predeterminer
 POS - Possessive ending
 PRP - Personal pronoun
 PRP\$ - Possessive pronoun (prolog version PRP-S)
 RB - Adverb
 RBR - Adverb, comparative
 RBS - Adverb, superlative
 RP - Particle
 SYM - Symbol
 TO - to
 UH - Interjection
 VB - Verb, base form
 VBD - Verb, past tense
 VBG - Verb, gerund or present participle
 VBN - Verb, past participle
 VBP - Verb, non-3rd person singular present
 VBZ - Verb, 3rd person singular present
 WDT - Wh-determiner
 WP - Wh-pronoun
 WP\$ - Possessive wh-pronoun (prolog version WP-S)
 WRB - Wh-adverb

9.3.4 Function tags. Form/function discrepancies

- ADV (adverbial) - marks a constituent other than ADVP or PP when it is used adverbially (e.g. NPs or free ("headless" relatives). However, constituents that themselves are modifying an ADVP generally do not get -ADV. If a more specific tag is available (for example, -TMP) then it is used alone and -ADV is implied. See the Adverbials section.
- NOM (nominal) - marks free ("headless") relatives and gerunds when they act nominally.

9.3.5 Function tags. Grammatical role

- DTV (dative) - marks the dative object in the unshifted form of the double object construction. If the preposition introducing the "dative" object is for, it is considered benefactive (-BNF). -DTV (and -BNF) is only used after verbs that can undergo dative shift.
- LGS (logical subject) - is used to mark the logical subject in passives. It attaches to the NP object of by and not to the PP node itself.
- PRD (predicate) - marks any predicate that is not VP. In the do so construction, the so is annotated as a predicate.
- PUT - marks the locative complement of put.
- SBJ (surface subject) - marks the structural surface subject of both matrix and embedded clauses, including those with null subjects.
- TPC ("topicalized") - marks elements that appear before the subject in a declarative sentence, but in two cases only:
 1. if the front element is associated with a *T* in the position of the gap.
 2. if the fronted element is left-dislocated (i.e. it is associated with a resumptive pronoun in the position of the gap).
- VOC (vocative) - marks nouns of address, regardless of their position in the sentence. It is not coindexed to the subject and not get -TPC when it is sentence-initial.

9.3.6 Function tags. Adverbials

Adverbials are generally VP adjuncts.

- BNF (benefactive) - marks the beneficiary of an action (attaches to NP or PP). This tag is used only when (1) the verb can undergo dative shift and (2) the prepositional variant (with the same meaning) uses for. The prepositional objects of dative-shifting verbs with other prepositions than for (such as to or of) are annotated -DTV.
- DIR (direction) - marks adverbials that answer the questions "from where?" and "to where?" It implies motion, which can be metaphorical as in "...rose 5 pts. to 57-1/2" or "increased 70% to 5.8 billion yen" -DIR is most often used with verbs of motion/transit and financial verbs.
- EXT (extent) - marks adverbial phrases that describe the spatial extent of an activity. -EXT was incorporated primarily for cases of movement in financial space, but is also used in analogous situations elsewhere. Obligatory complements do not receive -EXT. Words such as fully and completely are absolutes and do not receive -EXT.
- LOC (locative) - marks adverbials that indicate place/setting of the event. -LOC may also indicate metaphorical location. There is likely to be some variation in the use of -LOC due to differing annotator interpretations. In cases where the annotator is faced with a choice between -LOC or -TMP, the default is -LOC. In cases involving SBAR, SBAR should not receive -LOC. -LOC has some uses that are not adverbial, such as with place names that are adjoined to other NPs and NAC-LOC premodifiers of NPs. The special tag -PUT is used for the locative argument of put.
- MNR (manner) - marks adverbials that indicate manner, including instrument phrases.
- PRP (purpose or reason) - marks purpose or reason clauses and PPs.
- TMP (temporal) - marks temporal or aspectual adverbials that answer the questions when, how often, or how long. It has some uses that are not

strictly adverbial, such as with dates that modify other NPs at S- or VP-level. In cases of apposition involving SBAR, the SBAR should not be labeled -TMP. Only in "financialspeak," and only when the dominating PP is a PP-DIR, may temporal modifiers be put at PP object level. Note that -TMP is not used in possessive phrases.

9.3.7 Function tags. Miscellaneous

-CLR (closely related) - marks constituents that occupy some middle ground between arguments and adjunct of the verb phrase. These roughly correspond to "predication adjuncts", prepositional ditransitives, and some "phrasel verbs". Although constituents marked with -CLR are not strictly speaking complements, they are treated as complements whenever it makes a bracketing difference. The precise meaning of -CLR depends somewhat on the category of the phrase.

* on S or SBAR - These categories are usually arguments, so the -CLR tag indicates that the clause is more adverbial than normal clausal arguments. The most common case is the infinitival semi-complement of use, but there are a variety of other cases.

* on PP, ADVP, SBAR-PRP, etc - On categories that are ordinarily interpreted as (adjunct) adverbials, -CLR indicates a somewhat closer relationship to the verb. For example:

- o Prepositional Ditransitives

In order to ensure consistency, the Treebank recognizes only a limited class of verbs that take more than one complement (-DTV and -PUT and Small Clauses). Verbs that fall outside these classes (including most of the prepositional ditransitive verbs in class [D2]) are often associated with -CLR.

- o Phrasal verbs

Phrasal verbs are also annotated with -CLR or a combination of -PRT and PP-CLR. Words that are considered borderline between particle and adverb are often bracketed with ADVP-CLR.

- o Predication Adjuncts

Many of Quirk's predication adjuncts are annotated with -CLR.

* on NP - To the extent that -CLR is used on NPs, it indicates that the NP is part of some kind of "fixed phrase" or expression, such as take care of. Variation is more likely for NPs than for other uses of -CLR.

-CLF (cleft) - marks it-clefts ("true clefts") and may be added to the labels S, SINV, or SQ.

-HLN (headline) - marks headlines and datelines. Note that headlines and datelines always constitute a unit of text that is structurally independent from the following sentence.

-TTL (title) - is attached to the top node of a title when this title appears inside running text. -TTL implies -NOM. The internal structure of the title is bracketed as usual.